


1 INTRODUCERE

1.1. Filtre adaptive – caracteristici generale

1.1. Filtre adaptive – caracteristici generale

- Filtru adaptiv=filtru cu parametri reglabili+algoritm adaptiv recursiv
- Util în medii necunoscute sau nestaționare

Exemplu – filtru adaptiv FIR



$$e(n) = d(n) - y(n) = d(n) - \sum_{k=0}^{N-1} w_k^*(n)x(n-k) = d(n) - \mathbf{w}^H(n)\mathbf{x}(n)$$

$$\mathbf{w}(n) = [w_0(n), w_1(n), \dots, w_{N-1}(n)]^T, \quad \mathbf{w}^H(n) = (\mathbf{w}^T(n))^*$$

$$\mathbf{x}(n) = [x(n), x(n-1), \dots, x(n-N+1)]^T$$

Funcții cost

- - *eroarea medie pătratică* ,
$$E \left\{ |e^2(n)| \right\};$$
- - *suma pătratelor erorilor* (norma L_2 evaluată pe un suport finit)

$$\sum_{k=N}^M |e(n-k)|^2$$

Funcții cost

- - *suma ponderată a pătratelor erorilor*

$$\sum_{k=1}^n \lambda^{n-k} |e(n-k)|^2 \quad \lambda \in (0,1]$$

- - *norma L_1 a erorii evaluată pe un suport finit*


$$\sum_{k=0}^{N-1} |e(n-k)|$$

Caracteristici generale

- *viteza de convergență*
- *dezadaptarea*
- *capacitatea de urmărire a variațiilor statistice ale semnalelor*
- *robustețea*
- *complexitatea algoritmului*
- *structura*
- *proprietăți numerice*

Configurații de sisteme adaptive

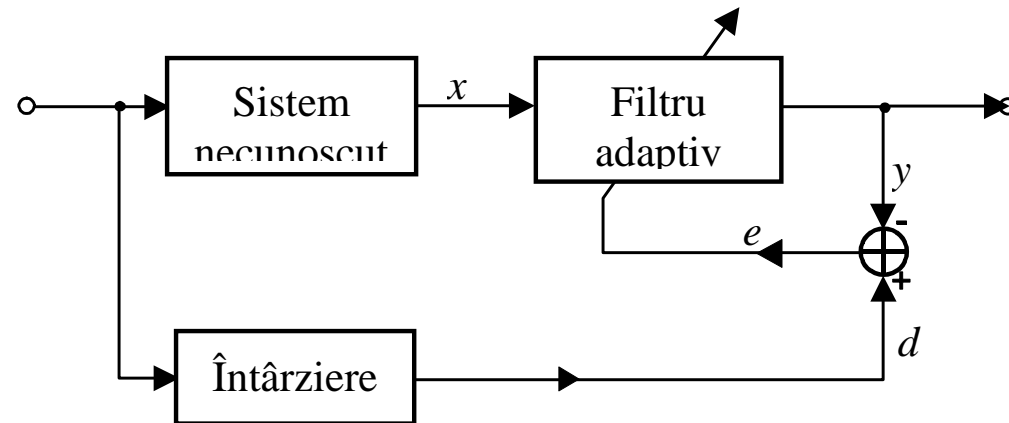
- 1.2.1 Identificarea sistemelor



Aplicații tipice:


- Modelarea canalului radio
- Modelarea adaptivă în explorările geofizice

1.2.2 Modelarea inversă




Aplicație tipică - Egalizarea automată

Egalizare automată




$$s(t) = \sum_{k=0}^{\infty} a_k p(t - kT_s); \quad a_k \in \{\pm 1, \pm 3, \dots, \pm 2M - 1\}$$

Egalizare automată



$$p(nT_s) = \begin{cases} 1, & n = 0 \\ 0, & n \neq 0 \end{cases}$$
$$s(mT_s) = a_m$$


1.2.3. Predicția



Aplicații tipice

- Codarea predictivă a semnalelor vocale
- Suprimarea unei interferențe de bandă îngustă suprapusă peste un semnal de bandă largă
- Intensificarea semnalului (suprimarea unui zgomot de banda largă)

Suprimarea interferențelor pe baza proprietăților de autocorelație




Predicția se bazează pe existența unei autocorelații.

Bandă îngustă \leftrightarrow timp de autocorelație mare (puternic corelat)

Bandă largă \leftrightarrow timp de autocorelație mic (slab corelat)

1.2.4 Suprimarea interferențelor



Semnalul primar = semnal util + semnal perturbator


Semnalul secundar = semnal corelat numai cu semnalul perturbator

Funcționează pe baza proprietăților de intercorelație – filtrul adaptiv
funcționează dacă există o anumită intercorelație între semnalul de intrare și semnalul dorit.

Aplicații tipice


- Suprimarea ecoului în transmisiunile de date pe canale telefonice (ecou electric)
- Suprimarea ecoului acustic
- Reducerea zgomotului în transmisiunile vocale
- Reducerea unei interferențe prin modificarea caracteristicii de directivitate a unui sistem de antene

Suprimarea ecoului electric



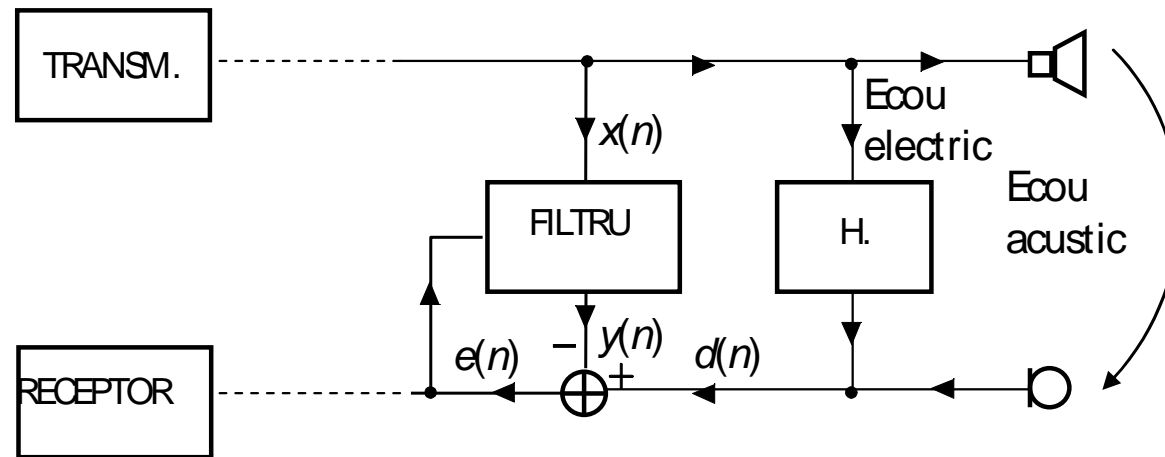
$$s_{RA}(t) = A_1 s_B(t) + A_2 s_A(t - d_1) + A_3 s_A(t - d_2) = A_1 s_B(t) + s_{EA}(t)$$

Suprimarea ecoului electric



Suprimarea ecoului electric

Conform G 168 ITU+T



2.1.3 Matricea de autocorelație a unui proces staționar - definiție

$$\mathbf{x}(n) = [x(n), x(n-1), \dots, x(n-N+1)]^T$$

$$\mathbf{R} = \mathbb{E}\{\mathbf{x}(n)\mathbf{x}^H(n)\} = \begin{bmatrix} r(0) & r(1) & \cdot & \cdot & \cdot & r(N-1) \\ r(-1) & r(0) & \cdot & \cdot & \cdot & r(N-2) \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ r(-N+1) & r(-N+2) & \cdot & \cdot & \cdot & r(0) \end{bmatrix}$$

$$r(k) = \mathbb{E}\{x^*(n)x(n+k)\} = \mathbb{E}\{x^*(n-k)x(n)\}$$

$$r_{ij} = r(j-i)$$

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

1. Hermitică: $\mathbf{R}^H = \mathbf{R}$

2. Toeplitz

3. Pozitiv semidefinită:

$$\mathbf{u}^H \mathbf{R} \mathbf{u} = \sum_{i=1}^N \sum_{j=1}^N r(j-i) \mathbf{u}_i^* \mathbf{u}_j \geq 0.$$

$$\mathbf{u}^H \mathbf{R} \mathbf{u} = \mathbf{u}^H \mathbb{E} \left\{ \mathbf{x}(n) \mathbf{x}^H(n) \right\} \mathbf{u} = \mathbb{E} \left\{ \mathbf{u}^H \mathbf{x}(n) \mathbf{x}^H(n) \mathbf{u} \right\} = \mathbb{E} \left\{ \left| \mathbf{u}^H \mathbf{x}(n) \right|^2 \right\} \geq 0.$$

4. $\mathbf{x}^B(n) = [x(n-N+1), x(n-N+2), \dots, x(n)]^T$

$$\mathbb{E} \left\{ \mathbf{x}^B(n) \mathbf{x}^{BH}(n) \right\} = \mathbf{R}^T.$$

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

5. Matricea de autocorelație extinsă și partiția ei.

Fie \mathbf{R} de dimensiune $N \times N$, \mathbf{R}_N și matricea de autocorelație extinsă de dimensiune $(N+1) \times (N+1)$, \mathbf{R}_{N+1} .

$$\mathbf{R}_{N+1} = \begin{bmatrix} r(0) & \mathbf{r}^H \\ \mathbf{r} & \mathbf{R}_N \end{bmatrix} = \begin{bmatrix} \mathbf{R}_N & \mathbf{r}^{B*} \\ \mathbf{r}^{BT} & r(0) \end{bmatrix}$$

unde

$$\mathbf{r}^H = [r(1), r(2), \dots, r(N)]$$

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

Proprietăți legate de valorile/vectorii proprii

Fie λ_i valorile proprii ale matricei \mathbf{R} , deci rădăcinile ecuației caracteristice

$$\det(\mathbf{R} - \lambda\mathbf{I}) = 0$$

și \mathbf{q}_i vectorii proprii asociați,

$$\mathbf{R}\mathbf{q}_i = \lambda_i\mathbf{q}_i, \quad i = 1, \dots, N.$$

6. Valorile proprii ale matricei \mathbf{R}^k , $k \in \mathbf{Z}$, sunt λ_i^k , $i=1,2,\dots,N$.

7. Dacă λ_i , $i=1,\dots,N$ sunt distincte, atunci vectorii \mathbf{q}_i sunt liniar independenți.

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

7. Dacă $\lambda_i, i=1, \dots, N$ sunt distincte, atunci vectorii \mathbf{q}_i sunt liniar independenți.

8. $\lambda_i \in \mathbf{R}_+, i = 1, \dots, N$

$$\lambda_i = \frac{\mathbf{q}_i^H \mathbf{R} \mathbf{q}_i}{\mathbf{q}_i^H \mathbf{q}_i} \geq 0$$

9. $\lambda_i \neq \lambda_j, i, j = 1, 2, \dots, N, i \neq j \Rightarrow \mathbf{q}_i, \mathbf{q}_j$ ortogonali,

$$\mathbf{q}_j^H \mathbf{q}_i = 0$$

Demonstrație. Conform definiției:

$$\mathbf{R} \mathbf{q}_i = \lambda_i \mathbf{q}_i, \mathbf{R} \mathbf{q}_j = \lambda_j \mathbf{q}_j$$

$$\mathbf{q}_j^H \mathbf{R} \mathbf{q}_i = \lambda_i \mathbf{q}_j^H \mathbf{q}_i \quad \longleftrightarrow \quad \mathbf{q}_j^H \mathbf{R}^H = \mathbf{q}_j^H \mathbf{R} = \lambda_j \mathbf{q}_j^H$$

$$(\lambda_i - \lambda_j) \mathbf{q}_j^H \mathbf{q}_i = 0$$

Se poate construi un set ortonormat de vectori proprii

$$\mathbf{q}_j^H \mathbf{q}_i = \begin{cases} 1, & i = j \\ 0, & i \neq j \end{cases}$$

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

10. *Diagonalizarea* matricei \mathbf{R}

$$\mathbf{Q}^H \mathbf{R} \mathbf{Q} = \Lambda$$

unde

$$\mathbf{Q} = [\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_N], \quad \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_N) \quad \lambda_i \neq \lambda_j$$

iar \mathbf{q}_i reprezintă un set ortonormal de vectori proprii. Matricea \mathbf{Q} este *unitară*:

$$\mathbf{Q}^H \mathbf{Q} = \mathbf{I}, \quad \text{sau} \quad \mathbf{Q}^{-1} = \mathbf{Q}^H.$$

Demonstrație

$$\mathbf{R} \mathbf{Q} = \mathbf{Q} \Lambda$$

și se înmulțește la stânga cu \mathbf{Q}^H .

Teorema lui Mercer (teorema spectrală):

$$\mathbf{R} = \mathbf{Q} \Lambda \mathbf{Q}^H = \sum_{i=1}^N \lambda_i \mathbf{q}_i \mathbf{q}_i^H.$$

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

11. *Urma matricei R*

$$\text{tr}(\mathbf{R}) = \sum_{i=1}^N \lambda_i$$
$$r(0) = \frac{1}{N} \sum_{i=1}^N \lambda_i.$$

12. *Norma spectrală* a unei matrice \mathbf{A}

$$\|\mathbf{A}\|_s = \left(\text{valoarea proprie maxima a matricei } \mathbf{A}^H \mathbf{A} \right)^{\frac{1}{2}}$$
$$\|\mathbf{R}\|_s = \lambda_{\max}.$$

Numărul condițional

$$\chi(\mathbf{A}) = \|\mathbf{A}\|_s \|\mathbf{A}^{-1}\|_s$$
$$\|\mathbf{R}\|_s = \lambda_{\max}, \quad \|\mathbf{R}^{-1}\|_s = \frac{1}{\lambda_{\min}}, \quad \Rightarrow \quad \chi(\mathbf{R}) = \frac{\lambda_{\max}}{\lambda_{\min}}$$

2.1.3 Matricea de autocorelație a unui proces staționar - proprietăți

13. *Câțul Rayleigh* asociat unui vector \mathbf{u} nenul, de dimensiune $N \times 1$

$$\frac{\mathbf{u}^H \mathbf{R} \mathbf{u}}{\mathbf{u}^H \mathbf{u}}$$

$$\lambda_{\min} = \min \frac{\mathbf{u}^H \mathbf{R} \mathbf{u}}{\mathbf{u}^H \mathbf{u}}, \quad \lambda_{\max} = \max \frac{\mathbf{u}^H \mathbf{R} \mathbf{u}}{\mathbf{u}^H \mathbf{u}}$$

14. $\min_{\omega} P_{xx}(e^{j\omega}) \leq \lambda_i \leq \max_{\omega} P_{xx}(e^{j\omega})$